



인공신경망을 이용한 321 스텐레스강의 고온 변형 유동응력 예측

송신형^{a,*}

Predicting Hot Deformation Flow Stress in 321 Stainless Steel Using a Neural Network Model

Shin-Hyung Song^{a,*}^a Department of Smart Automobile, Soonchunhyang University

ARTICLE INFO

Article history:

Received	31	December	2025
Revised	4	February	2026
Accepted	12	February	2026

Keywords:

321 stainless steel
Neural network
Flow stress
Hot deformation

ABSTRACT

Grade 321 stainless steel exhibits many superior characteristics and has been adopted in a wide variety of applications across different fields. In this study, a flow stress model based on a neural network was developed for 321 stainless steel deforming at temperatures ranging from 700°C to 900°C and strain rates of 0.0002/s-0.02/s. After training the model with a feedforward multilayer perceptron architecture, the performance of the model was evaluated in terms of the mean squared error (MSE) and mean absolute percentage error (MAPE). The distribution of errors was also examined. The distribution of errors and the overall performance of the model were investigated and discussed. Overall, the results show that the predicted values output by the trained model were relatively accurate.

1. 서론

321 스텐레스강은 티타늄을 주요 합금 원소로 하며 부식저항성 및 고온에서의 성질 및 성형성이 우수하다^[1].

금속재료의 변형 시 유동응력의 변화에 관한 모델링 연구는 매우 중요한데 이는 유동응력 모델과 유한요소기법을 적용하여 고온 환경에서의 변형 거동을 예측하는 등^[2] 이를 각종 기계의 설계에 반영할 수 있기 때문이다. 321 스텐레스강은 1000°C 근처에서 동적 재결정이 일어난다고 알려져 있으며^[3] 이에 따라 321 스텐레스강의 동적재결정 온도 주변 범위에서 고온 유동응력 모델링에 관한 연구가 이루어졌다^[3-5]. 하지만 321 스텐레스강의 1000°C 이하의 온도범위의 유동응력의 모델링에 관한 연구는 현재까지 미진한 편이다.

321 스텐레스강과 같은 금속재료의 고온에서의 유동응력은 구성방정식의 형태로 모델링하는 것이 일반적인데 회귀분석의 방법을 사용하는 이러한 구성방정식 형태의 모델은 예측을 함에 있어 종종 오차가 발생한다. 이는 종속변수인 유동응력과 변형률속도, 변형률, 온도 등을 비롯한 각종 공정변수들과의 관계가 비선형적이며 매우 복잡하기 때문이다. 또한 구성방정식 모델을 완성하는데 많은 시간이 소요되는 경우가 있으며 모델을 완성하는데 각종 복잡한 계산과정을 거치는 경우가 많다.

최근에는 기존 구성방정식을 적용하는 방식과 다르게 기계학습을 적용하여 금속재료의 유동응력을 예측하는 연구가 활발하다. 예를 들어 각종 금속재료의 고온 유동응력 모델링에 인공신경망^[6-8], 서포트벡터^[9,10] 등이 적용되었다. 이들 기계학습을 적용한 유동응력 예측모델은 비선형적인 종속변수 및 공정변수들 간의

* Corresponding author. Tel.: +82-41-530-4987

E-mail address: neuro2@sch.ac.kr (Shin-Hyung Song).



Fig. 1 Test device^[11]

관계를 매우 효과적으로 연결지어 기존 구성방정식 형태의 모델들에 비하여 높은 예측 정확도를 보이는 것으로 나타났다.

본 연구에서는 321 스테레스강의 온도 700°C ~900°C와 변형률 속도 0.0002/s~0.02/s 범위에서의 고온변형 유동응력 예측모델을 개발하였다. 예측모델의 개발에는 전통적인 형태의 구성방정식이 아닌 최근 활발히 유동응력의 모델링에 적용되는 인공신경망을 적용하였으며 개발된 예측모델로 도출된 예측값들의 오차를 분석하고 오차의 분포를 연구하여 321 스테레스강의 상기 범위에서의 유동응력의 모델링에 인공신경망을 적용하는 것의 적절성을 관찰하였다.

2. 고온 인장시험

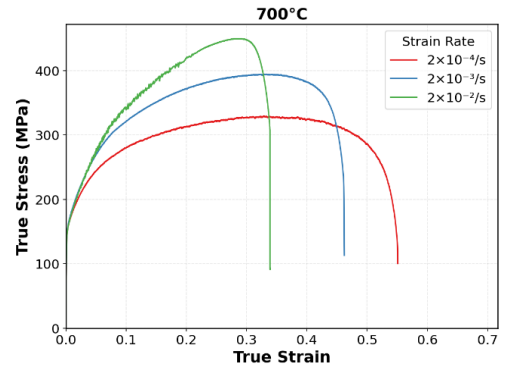
2.1 고온 인장시험

321 스테레스강의 700°C~900°C 및 0.0002/s, 0.002/s, 0.02/s의 변형률속도 범위에서의 고온변형 유동응력 예측모델 개발에는 저자가 이전에 연구한^[11] 실험데이터가 사용되었다. 고온 변형시험 데이터 수집을 위하여 MTS-810 시험장비를 이용한 고온 인장시험이 수행되었으며 고온 변형시험의 시편은 ASTM-E8 기준에 따라 제작되었다. Fig. 1은 실험에 사용된 시험장치를 보여주고 있다. Fig. 2는 측정된 고온변형 시험의 true stress-true strain 곡선을 나타낸 것이다. 전체적으로 온도가 증가할수록 응력은 감소하며 변형률속도가 증가할수록 응력은 증가하는 추세를 보이고 있다.


2.2 인공신경망

인공신경망은 인간두뇌의 뉴런조직의 작동을 모방하는 기계학습 알고리즘이다. 인공신경망은 많은 변수들 간의 비선형적이며 복잡한 관계를 높은 정확도로 모델링하는데 탁월한 성능을 발휘하며 현대의 기계학습 분야에서 가장 많은 응용분야에 적용되는 알고리즘 중 하나가 되었다.

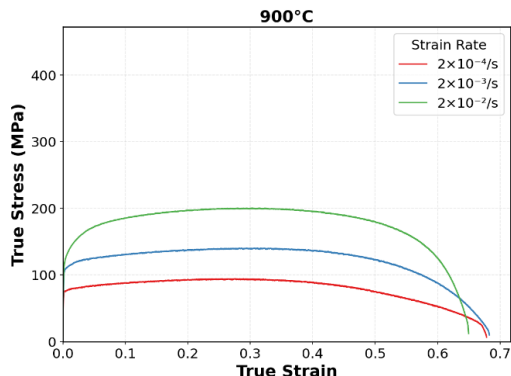
인공신경망의 기본구조는 노드 또는 뉴런이라고 불리는 단위가



(a)



(b)



(c)

Fig. 2 Stress-strain graph at temperature of (a) 700°C (b) 800°C (c) 900°C

층(layer)에 배치되는 형태로 층의 갯수와 각 층에 배치되는 노드의 개수는 자유롭게 결정한다. 최초의 층은 입력층이라 불리며 입력값에 해당하는 독립변수를 처리한다. 신경망구조의 마지막에 존재하는 출력층은 출력변수이자 종속변수를 배출한다. 입력층과 출력층 사이의 층들은 은닉층이라고 한다. 이전 층의 각 노드는 가중치(weight)를 통하여 다음 층의 노드들에 영향을 전달하며 이런 방식을 거쳐서 특정노드는 이전 층 노드들에서 받은 전체 영향을 더하고 여기에 편향(bias)을 더하여 활성화함수(activation function)를 거쳐서 최종값을 생성하며 이렇게 다시 다음 층의 노드들에 영향을

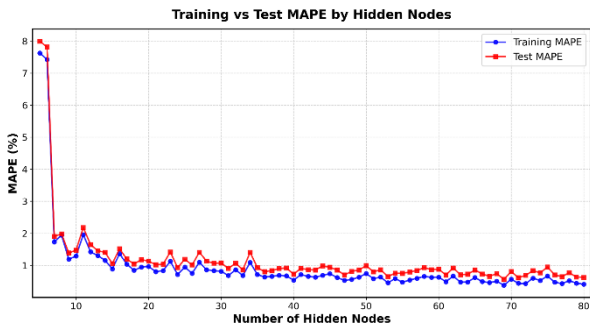


Fig. 3 Training / Test MAPE vs node numbers




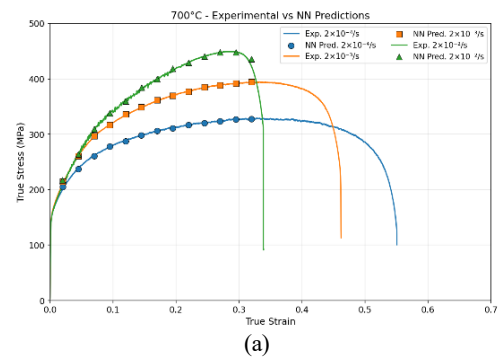
Fig. 4 Schematic diagram of a neural network with 7 nodes in each hidden layer

전달한다. 데이터를 이용한 신경망의 학습에서는 출력층을 통하여 배출된 종속변수의 오차를 계산하고 출력층으로부터 입력층으로 역전파 알고리즘을 거치는 과정을 통하여 각 노드가 오차에 미친 기여도를 산출하여 이를 바탕으로 각 노드의 가중치 및 편향을 매번 수정한다. 신경망 학습에서는 이렇게 순방향전파와 역방향 전파를 반복하며 신경망의 최적화를 수행한다.


이 연구에서는 순방향 다층 퍼셉트론(feed forward multi-layer perceptron) 신경망을 적용하여 유동응력의 예측모델을 개발하였다. 입력층은 온도, 변형률속도, 변형률을 나타내는 3개 노드가 있으며 은닉층은 2개가 있다. 출력층에는 유동응력을 나타내는 1개 노드가 존재한다. 은닉층의 활성화함수로는 ReLU 함수가 사용되었으며 출력층의 활성화함수는 Linear 함수가 사용되었다. 신경망 학습의 계산에는 미니배치 경사하강법(mini-batch gradient descent method)을 적용하였다. 신경망 계산에 사용된 파라미터 중 Learning rate는 0.001, epochs는 1000 그리고 batch-size는 1로 설정되었다. 손실함수로는 Mean Squared Error (MSE)가 사용되었다.

신경망 훈련에 사용된 데이터는 소성변형 구간을 주된 영역으로 하는 탐구영역에서 추출하였는데 먼저 각 곡선에서 변형률을 0.02에서 0.32까지 0.025의 증분을 가지고 분포하게 하는 13개 지점을 test dataset으로 지정하였으며 각 곡선 별로 52개씩의 임의의 점들을 추출하여 training dataset으로 지정하였다. 이렇게 하여 training dataset과 test dataset의 총 크기는 각각 468개 및 117개, 비율은 80:20이 되도록 하였다.


인공신경망의 구조 최적화는 은닉층의 노드 수를 조절하는 방식으로 이루어졌다. 최적의 은닉층 노드 개수를 도출하기 위하여 노드 수를 5부터 80까지 증가시키며 각 노드 개수에 따른 신경망 예측의 성능을 관찰하였으며 모든 연산에 training dataset에 대한 5-fold 교차검증을 적용하였다. 이 때 training dataset과 test dataset의 MSE 및 MAPE를 관찰하였는데 Fig. 3은 노드 수의 증가에 따른 training dataset의 MSE와 test dataset의 MSE의 변화를 나타낸 것이다. Training dataset과 test dataset의 오차가 감



(a)



(b)



(c)

Fig. 5 Stress vs strain curves after predictions

소하다가 점차 수렴하는 추세를 보이는데 이러한 추세 및 과적합 가능성을 고려하여 신경망의 최적 노드 개수를 69개로 결정하였다. 이때 노드 수 69개에서의 5-fold 교차검증을 적용한 정확한

MSE 값은 training MSE와 test MSE의 경우 각각 1.046 ± 0.064 (표준편차) 및 2.523 ± 0.457 (표준편차)였다. MAPE 값은 training dataset과 test dataset이 0.381 ± 0.016 및 0.565 ± 0.033 이었다. MSE와 MAPE의 training/test 차이는 각각 1.48 및 0.18%였다.

Fig. 4에서는 은닉층의 노드 개수가 예를 들어 7개일 때의 인공 신경망의 개념도를 나타낸다.

2.3 결과분석

Fig. 5에서는 실험값의 그래프와 인공신경망 모델로 예측한 값을 함께 표시하였다. 그림에 나타난 것과 같이 대부분의 영역에서 매우 높은 정밀도로 예측이 이루어짐을 알 수 있다. 일부에서는 오차가 눈에 띄게 발생하는 영역이 발견되는데 예를 들어 700°C의 변형률속도 0.02/s인 곡선 및 800의 변형률속도 0.002/s 및 0.02/s인 곡선 등이다. 개발된 인공신경망 예측모델의 Mean Squared Error (MSE)는 약 4.6690이었으며 Mean Absolute Percentage Error (MAPE)는 약 0.6200%인 것으로 나타났다. 또한 오차의 결정계수 R^2 은 0.9995였으며 표준편차는 2.130인 것으로 나타났다. 따라서 수치로 관찰되는 전체적인 예측의 정밀도는 매우 우수한 것으로 나타났다.

오차의 발생 분포를 구체적으로 살펴보기 위하여 Fig. 6에 산포도를 표시하였다. 다른 온도의 데이터는 다른 색상의 점으로 표시하였다. 그림에서 알 수 있듯이 대부분의 예측값들은 완전일치선 (line of perfect agreement)에 매우 가까운 것으로 나타났다. 또 일부에서 눈에 띄는 오차를 가진 점들이 존재하나 온도의 증감과 예측 오차의 증감은 특별한 상관관계가 존재하지 않는 것으로 보인다. Fig. 5 및 Fig. 6를 관찰하며 온도에 더하여 변형률속도까지 고려하면 앞에 기술한 바와 같이 오차의 발생과 고온변형의 공정 변수들 간의 뚜렷한 관계는 보이지 않았다.

산포도를 도출하여 오차의 전체적인 분포를 분석한 후 오차 크기별 발생 빈도를 탐구하기 위하여 상대도수(relative frequency)대 부호 있는 상대오차(signed relative error)의 히스토그램을 Fig. 7에 표시하였다. 오차의 분포는 0을 중심으로 어느정도 대칭의 형태를 보이지만 우수한 정규분포의 형태는 아니며 불규칙한 쪽에 가깝다.

또한, 온도 및 변형률속도에 따른 구체적인 오차를 관찰하기 위하여 Mean absolute percentage error (MAPE)를 표시한 heatmap을 도출하여 Fig. 8에 표시하였다. 오차의 분포는 대부분 1 미만의 MAPE 수치를 보이면서 우수한 형태를 보이는데 700°C 및 0.02/s 및 900°C의 0.0002/s, 0.002/s에서와 같이 상대적으로 높은 수치도 확인할 수 있다. 하지만 전체적인 분포는 대체적으로 작은 수치들을 보이며 수치들 간의 차이도 미미하여 오차와 고온 변형의 변수들 간에 뚜렷한 관계가 있다고 말하기는 어려운 것으

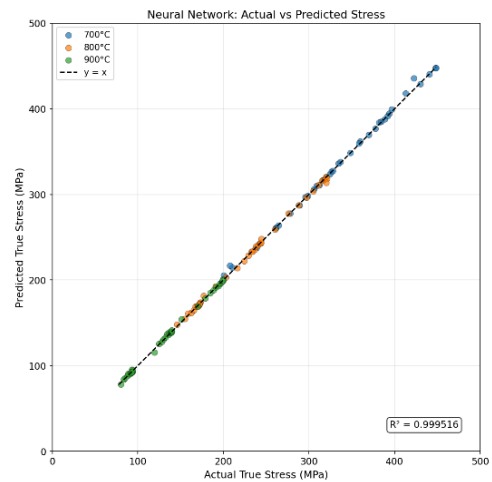


Fig. 6 Scatter plot

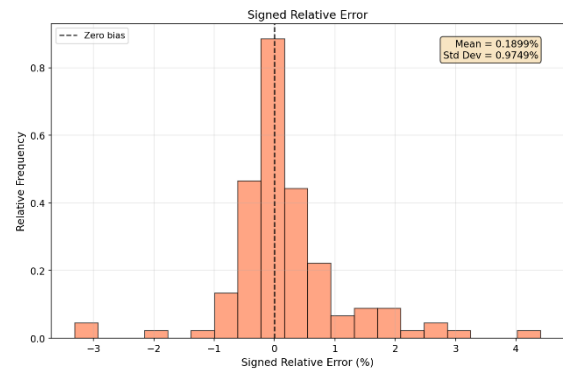


Fig. 7 Relative frequency vs signed relative error

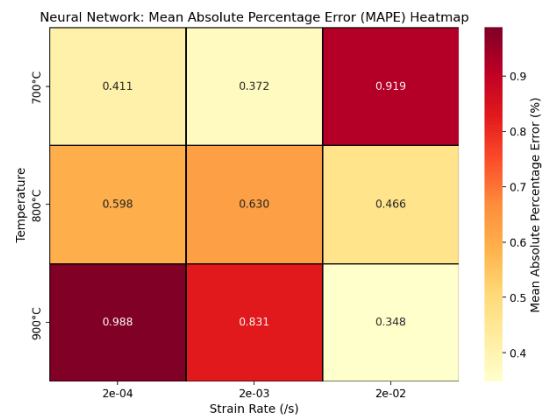


Fig. 8 Heatmap of MAPE

로 보인다.

3. 결론

본 연구에서는 321 스텐레스강의 고온 변형 유동응력을 인공신경망을 이용하여 모델링하였다. 예측한 값들은 Mean Squared Error (MSE)가 약 4.6690이었으며 Mean Absolute Percentage

Error (MAPE)가 약 0.6200%로 예측모델의 예측 정확도는 매우 우수하였다. 오차의 결정계수는 0.9995이었으며 표준편차는 2.130이었다. 오차 발생의 구체적인 분포를 관찰하기 위한 산포도, 히스토그램, Heatmap 분석에서는 오차 발생의 정도와 고온변형의 공정변수 간의 특별한 관계는 보이지 않았다. 본 연구에서 개발된 인공지능망은 지도학습 방식의 인공지능 예측모델이며 재료의 고온변형 등에 관한 물리현상의 이론이 반영되지 않는다는 특징이 있는데 이것이 오차분포의 불규칙성과 관계가 있을 수 있다는 추정이 가능하나 보다 정확한 분석 및 토의를 위하여 추가적인 인공지능 알고리즘 등 다양한 형태의 예측모델 개발이 필요하다 생각된다.

References

- [1] Nkhoma, R. K. C., Siyasiya, C. W., Stumpf, W. E., 2014, Hot Workability of AISI 321 and AISI 304 Austenitic Stainless Steels, *J. Alloys Compd.*, 595 103-112, <https://doi.org/10.1016/j.jallcom.2014.01.157>.
- [2] Seo, J., Park, H. W., 2022, Prediction of Thermomechanical Deformation of Spindle Unit using Finite Element Method, *J. Korean Soc. Manuf. Technol. Eng.*, 31:5 299-305, <https://doi.org/10.7735/ksmte.2022.31.5.299>.
- [3] Zhao, D., Ren, L., Wang, Y., Wang, W., Zhu, Z., Fu, W., 2021, Hot Deformation Behaviors of as Cast 321 Austenitic Stainless Steel, *Metals*, 11:8 1245. <https://doi.org/10.3390/met11081245>
- [4] Haj, M., Mansouri, H., Vafaei, R., Ebrahimi, G. R., Kanani, A., 2013, Hot Compression Deformation Behavior of AISI 321 Austenitic Stainless Steel, *Int. J. Miner. Metall. Mater.*, 20 529-534, <https://doi.org/10.1007/s12613-013-0761-0>.
- [5] Ghazani, M. S., Eghbali, B., 2019, Modeling the Flow Behavior of AISI 321 Austenitic Stainless Steel Using a Simple Combined Phenomenological Method, *Mech. Mater.*, 137 103108, <https://doi.org/10.1016/j.mechmat.2019.103108>.
- [6] Haghdadadi, N., Zarei-Hanzaki, A., Khalesian, A. R., Abedi, H. R., 2013, Artificial Neural Network Modeling to Predict the Hot Deformation Behavior of an A356 Aluminum Alloy, *Mater. Des.*, 49 386-391, <https://doi.org/10.1016/j.matdes.2012.12.082>.
- [7] Zhao, J., Ding, H., Zhao, W., Huang, M., Wei, D., Jiang, Z., 2014, Modelling of the Hot Deformation Behaviour of a Titanium Alloy Using Constitutive Equations and Artificial Neural Network, *Comput. Mater. Sci.*, 92 47-56, <https://doi.org/10.1016/j.commatsci.2014.05.040>.
- [8] Senthilkumar, V., Balaji, A., Arulkirubakaran, D., 2013, Application of Constitutive and Neural Network Models for Prediction of High Temperature Flow Behavior of Al/Mg Based Nanocomposite, *Trans. Nonferrous Met. Soc. China*, 23:6 1737-750, [https://doi.org/10.1016/S1003-6326\(13\)62656-4](https://doi.org/10.1016/S1003-6326(13)62656-4).
- [9] Desu, R. K., Guntuku, S. C., Gupta, A. K., 2014, Support Vector Regression Based Flow Stress Prediction in Austenitic Stainless Steel 304, *Procedia Mater. Sci.*, 6 368-375, <https://doi.org/10.1016/j.mspro.2014.07.047>.
- [10] Rakhshkhorshid, M., Mollayi, N., Maldar, A. R., 2017, A SVM Model to Predict the Hot Deformation Flow Curves of AZ91 Magnesium Alloy, *Iranian Journal of Materials Forming*, 4:2 15-24.
- [11] Song, S.-H., 2019, Study on Hot Deformation of 321 Stainless Steel, *Soonchunhyang J. Nat. Sci.*, 25:1 79-83, <https://m.riss.kr/search/detail/DetailView.do?p_mat_type=1a0202e37d52c72d&control_no=3f870625177c54ace9810257f7042666#redirect>.



Shin-Hyung Song

Professor in the Department of Smart Automobile, Soonchunhyang University. His research interests include machine design.
E-mail: neuro2@sch.ac.kr